林轩田《机器学习基石》课程笔记1 -- The Learning Problem

作者: 红色石头 公众号: Al有道 (id: redstonewill)


最近在看NTU林轩田的《机器学习基石》课程,个人感觉讲的非常好。整个基石课程 分成四个部分:

- When Can Machine Learn?
- Why Can Machine Learn?
- How Can Machine Learn?
- How Can Machine Learn Better?


每个部分由四节课组成,总共有16节课。那么,从这篇开始,我们将连续对这门课做课程笔记,共16篇,希望能对正在看这们课的童鞋有所帮助。下面开始第一节课的笔记: The Learning Problem。

— What is Machine Learning

什么是"学习"? 学习就是人类通过观察、积累经验,掌握某项技能或能力。就好像我们从小学习识别字母、认识汉字,就是学习的过程。而机器学习 (Machine Learning),顾名思义,就是让机器 (计算机)也能向人类一样,通过观察大量的数据和训练,发现事物规律,获得某种分析问题、解决问题的能力。



机器学习可以被定义为: Improving some performance measure with experence computed from data. 也就是机器从数据中总结经验,从数据中找出某种规律或者模型,并用它来解决实际问题。



什么情况下会使用机器学习来解决问题呢?其实,目前机器学习的应用非常广泛,基本上任何场合都能够看到它的身影。其应用场合大致可归纳为三个条件:

- 事物本身存在某种潜在规律
- 某些问题难以使用普通编程解决
- 有大量的数据样本可供使用
 - exists some 'underlying pattern' to be learned
 so 'performance measure' can be improved
 - but no programmable (easy) definition
 —so 'ML' is needed
- somehow there is data about the pattern
 so ML has some 'inputs' to learn from

二、Applications of Machine Learning

机器学习在我们的衣、食、住、行、教育、娱乐等各个方面都有着广泛的应用,我们的生活处处都离不开机器学习。比如,打开购物网站,网站就会给我们自动推荐我们可能会喜欢的商品;电影频道会根据用户的浏览记录和观影记录,向不同用户推荐他们可能喜欢的电影等等,到处都有机器学习的影子。

三、Components of Machine Learning


本系列的课程对机器学习问题有一些基本的术语需要注意一下:

- 輸入x
- 输出y
- 目标函数f, 即最接近实际样本分布的规律
- 训练样本data
- 假设hypothesis,一个机器学习模型对应了很多不同的hypothesis,通过演算法A,选择一个最佳的hypothesis对应的函数称为矩g,g能最好地表示事物的内在规律,也是我们最终想要得到的模型表达式。

Basic Notations

- input: $\mathbf{x} \in \mathcal{X}$ (customer application)
- output: y ∈ Y (good/bad after approving credit card)
- unknown pattern to be learned ⇔ target function:
 f: X → Y (ideal credit approval formula)
- data \Leftrightarrow training examples: $\mathcal{D} = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \cdots, (\mathbf{x}_N, y_N)\}$ (historical records in bank)
- hypothesis ⇔ skill with hopefully good performance:
 g: X → Y ('learned' formula to be used)

实际中, 机器学习的流程图可以表示为:



对于理想的目标函数f,我们是不知道的,我们手上拿到的是一些训练样本D,假设是监督式学习,其中有输入x,也有输出y。机器学习的过程,就是根据先验知识选择模

型,该模型对应的hypothesis set (用H表示),H中包含了许多不同的hypothesis,通过演算法A,在训练样本D上进行训练,选择出一个最好的hypothes,对应的函数表达式g就是我们最终要求的。一般情况下,g能最接近目标函数f,这样,机器学习的整个流程就完成了。

四、Machine Learning and Other Fields

与机器学习相关的领域有:

- 数据挖掘 (Data Mining)
- 人工智能 (Artificial Intelligence)
- 统计 (Statistics)

其实,机器学习与这三个领域是相通的,基本类似,但也不完全一样。机器学习是这三个领域中的有力工具,而同时,这三个领域也是机器学习可以广泛应用的领域,总得来说,他们之间没有十分明确的界线。

五、总结

本节课主要介绍了什么是机器学习,什么样的场合下可以使用机器学习解决问题,然后用流程图的形式展示了机器学习的整个过程,最后把机器学习和数据挖掘、人工智能、统计这三个领域做个比较。本节课的内容主要是概述性的东西,比较简单,所以笔记也相对比较简略。

这里附上林轩田 (Hsuan-Tien Lin) 关于这门课的主页:

http://www.csie.ntu.edu.tw/~htlin/

注明:

文章中所有的图片均来自台湾大学林轩田《机器学习基石》课程。